

Aritmética computacional

5. Representação de ponto flutuante

Ponto flutuante

- Representação de números não inteiros
 - Incluindo muito pequenos e muito grandes
- Parte da notação científica
 - -2.34×10^{56} ← normalizado
 - $+0.002 \times 10^{-4}$ ← não normalizado
 - $+987.02 \times 10^9$ ← não normalizado
- Em binário:
 - $\pm 1.xxxxxx_2 \times 2^{yyyy}$
- Tipos `float` e `double` em C

Padrão de ponto flutuante

- Definido pela norma IEEE 754-1985
- Desenvolvido para padronizar as representações
 - Problemas de portabilidade para código científico
- Atualmente, é adotado mundialmente
- Duas representações
 - Precisão simples (32-bit)
 - Precisão dupla (64-bit)

Formato de ponto flutuante

simples: 8 bits
duplo: 11 bits

simples: 23 bits
duplo: 52 bits



$$x = (-1)^S \times (1 + \text{Fraction}) \times 2^{(\text{Exponent} - \text{Bias})}$$

- S: bit de sinal (0 \Rightarrow não negativo, 1 \Rightarrow negativo)
- Significando normalizado: $1.0 \leq |\text{significando}| < 2.0$
 - Fração: o que aparece à direita do ponto
 - Significando: o número completo, incluindo o 1.
 - Sempre possui o bit 1 à esquerda do ponto binário, portanto este não precisa ser representado explicitamente (bit escondido)
- Expoente: representação por excesso: expoente verdadeiro + Bias
 - Garante que o expoente é sempre sem sinal
 - Precisão simples: Bias = 127; precisão dupla: Bias = 1023

Capacidade da precisão simples

- Expoentes 00000000 e 11111111 são reservados para uma representação especial
- Menor valor representável
 - Exponent: 00000001
 \Rightarrow expoente verdadeiro = $1 - 127 = -126$
 - Fração: 000...00 \Rightarrow significando = 1.0
 - $\pm 1.0 \times 2^{-126} \approx \pm 1.2 \times 10^{-38}$
- Maior valor
 - expoente: 11111110
 \Rightarrow expoente verdadeiro = $254 - 127 = +127$
 - Fração: 111...11 \Rightarrow significando ≈ 2.0
 - $\pm 2.0 \times 2^{+127} \approx \pm 3.4 \times 10^{+38}$

Capacidade da precisão dupla

- Expoentes 0000...00 e 1111...11 são reservados para uma representação especial
- Menor valor
 - Expoente: 00000000001
 \Rightarrow expoente verdadeiro = $1 - 1023 = -1022$
 - Fração: 000...00 \Rightarrow significando = 1.0
 - $\pm 1.0 \times 2^{-1022} \approx \pm 2.2 \times 10^{-308}$
- Maior valor
 - Expoente: 11111111110
 \Rightarrow expoente verdadeiro = $2046 - 1023 = +1023$
 - Fração: 111...11 \Rightarrow significando ≈ 2.0
 - $\pm 2.0 \times 2^{+1023} \approx \pm 1.8 \times 10^{+308}$

Precisão de um ponto flutuante

- Precisão relativa
 - Todos os bits da fração são significantes
 - Precisão simples: aprox. 2^{-23}
 - Equivalente a $23 \times \log_{10} 2 \approx 23 \times 0.3 \approx 6$ casas decimais de precisão
 - Precisão dupla: aprox. 2^{-52}
 - Equivalente a $52 \times \log_{10} 2 \approx 52 \times 0.3 \approx 16$ casas decimais de precisão

Exemplo de ponto flutuante

- Representar -0.75
 - $-0.75 = (-1)^1 \times 1.1_2 \times 2^{-1}$
 - $S = 1$
 - Fração = $1000\dots00_2$
 - Expoente = $-1 + \text{Bias}$
 - Simples: $-1 + 127 = 126 = 01111110_2$
 - Dupla: $-1 + 1023 = 1022 = 01111111110_2$
- Simples: $1011111101000\dots00$
- Dupla: $1011111111101000\dots00$

Exemplo de ponto flutuante

- Que número é representado pelo ponto flutuante de precisão simples:

11000000101000...00

- $S = 1$
 - Fração = $01000...00_2$
 - Expoente = $10000001_2 = 129$
- $x = (-1)^1 \times (1 + 01_2) \times 2^{(129 - 127)}$
 $= (-1) \times 1.25 \times 2^2$
 $= -5.0$